

## ЗАСТОСУВАННЯ БАГАТОШАРОВИХ ПЕРСЕПТРОНІВ ДЛЯ КЛАСИФІКАЦІЇ ПОЗИЧАЛЬНИКІВ-ЮРИДИЧНИХ ОСІБ

О. В. Григорович

Магістр з економічної кібернетики,  
аспірант кафедри економіко-математичного моделювання  
Державний вищий навчальний заклад «Київський національний  
економічний університет імені Вадима Гетьмана»

проспект Перемоги, 54/1, м. Київ, 03680, Україна

*olha.hryhorovych@gmail.com*

---

Статтю присвячено пошуку оптимальної архітектури нейронної мережі типу багатошаровий персептрон для мінімізації похибки першого роду при вирішенні задачі класифікації позичальників-юридичних осіб за рівнем кредитоспроможності. Проведено експериментальні дослідження із більше ніж 3000 моделями персептронного типу в інструментальному пакеті STATISTICA Neural Networks. Зроблено висновки і рекомендації щодо поділу генеральної сукупності спостережень на навчальну, тестову та контрольну вибірки з метою підвищення ефективності діагностування позичальників, котрим загрожує дефолт. Виявлено, що оптимальна кількість пояснювальних змінних для адекватної оцінки кредитоспроможності юридичних осіб має бути більшою 10. За таких умов середня точність передбачення дефолтів позичальників становить 80,23 % (відповідно, помилка першого роду є меншою за 20 %). Для найбільш адекватних моделей, відібраних у ході дослідження, похибка першого роду становить 10,69 %–13,69 %. Отримані експериментальні розрахунки підтверджують можливість і доцільність практичного застосування нейронних мереж персептронного типу при оцінці кредитоспроможності позичальників-юридичних осіб.

**Ключові слова:** *кредитоспроможність, нейронна мережа, багатошаровий персептрон, фінансові показники, класифікація, юридична особа.*

## ПРИМЕНЕНИЕ МНОГОСЛОЙНЫХ ПЕРСЕПТРОНОВ ДЛЯ КЛАССИФИКАЦИИ ЗАЕМЩИКОВ-ЮРИДИЧЕСКИХ ЛИЦ

О. В. Григорович

Магистр по экономической кибернетике,  
аспирант кафедры экономико-математического моделирования  
Государственное высшее учебное заведение «Киевский национальный  
экономический университет имени Вадима Гетьмана»

проспект Победы, 54/1, г. Киев, 03680, Украина

*olha.hryhorovych@gmail.com*

---

Статья посвящена поиску оптимальной архитектуры нейронной сети типа многослойный персептрон с целью минимизации ошибок

ки первого рода при решении задачи классификации заемщиков-юридических лиц по уровню кредитоспособности. Проведены экспериментальные исследования с более чем 3000 моделями перцептронного типа в инструментальном пакете STATISTICA Neural Networks. Сделаны выводы и рекомендации по разделению генеральной совокупности наблюдений на учебную, тестовую и контрольную выборки с целью повышения эффективности диагностирования заемщиков, которым грозит дефолт. Выявлено, что оптимальное количество объясняющих переменных для адекватной оценки кредитоспособности юридических лиц должно превышать 10. При таких условиях средняя точность предсказания дефолтов заемщиков составляет 80,23 % (соответственно, ошибка первого рода меньше 20 %). Для наиболее адекватных моделей, отобранных в ходе исследования, ошибка первого рода составляет 10,69 %–13,69 %. Полученные экспериментальные расчеты подтверждают возможность и целесообразность практического применения нейронных сетей перцептронного типа при оценке кредитоспособности заемщиков-юридических лиц.

**Ключевые слова:** кредитоспособность, нейронная сеть, многослойный перцептрон, финансовые показатели, классификация, юридическое лицо.

## APPLICATION OF MULTILAYER PERCEPTRONS TO LEGAL ENTITIES BORROWERS CLASSIFICATION

Olha Hryhorovych

Master's Degree in Economic Cybernetics,  
PhD student, Department of Economic and Mathematical Modeling  
State Higher Educational Establishment  
"Kyiv National Economic University named after Vadym Hetman"

54/1 Peremogy Avenue, Kyiv, 03680, Ukraine  
[olha.hryhorovych@gmail.com](mailto:olha.hryhorovych@gmail.com)

The article is devoted to the search for the optimal architecture of a neural network such as a multilayer perceptron in order to reduce the type I error in solving the problem of classifying borrowers-legal entities by credit level. Experimental studies have been conducted with more than 3000 multilayer perceptron models in the STATISTICA Neural Networks toolbox. Conclusions and recommendations have been made regarding the dividing dataset into training, test and validation samples to improve prediction of the borrower's default. It was revealed that the optimal number of explanatory variables for an adequate assessment of the creditworthiness of legal entities should exceed 10. Under such conditions, the average accuracy of prediction of defaults of borrowers is 80.23 % (respectively, the type I error is less than 20 %). For the most adequate models selected during the study, the type I error is 10.69 %–13.69 %. The obtained experimental calculations confirm the

possibility and expediency of the practical application of perceptron-type neural networks in assessing the creditworthiness of borrowers-legal entities.

**Keywords:** *creditworthiness, neural network, multilayer perceptron, financial indicators, classification, legal entity.*

**JEL Classification:** G21, C45, C51

**Постановка проблеми.** Ефективне функціонування кредитного ринку є однією з передумов стабільності фінансової системи країни, а також створює умови для економічного зростання. На жаль, ринок кредитування в Україні піддається впливу низки негативних зовнішніх (платежі за зовнішнім боргом, уповільнення зростання ВВП, військовий конфлікт, відчуження територій і втрата ринків збуту) і внутрішніх (низькі кредитні стандарти, нехтування лімітами концентрації боргів, кредитування пов'язаних осіб, високий обсяг валютного кредитування) чинників, що стають основою масових дефолтів за боргами. За часткою непрацюючих кредитів Україна є лідером серед країн Європи та Азії. У країнах ЄС даний показник не перевищує 5 %, а у кредитному портфелі вітчизняних платоспроможних банків частка непрацюючих кредитів становить 50 % [1].




Рис. 1. Динаміка частки непрацюючих кредитів у портфелях банків

Джерело: [2]

Як бачимо, протягом останніх років в Україні спостерігається позитивна динаміка зниження частки непрацюючих кредитів у портфелях банків, однак скорочення частки непрацюючих кредитів суб'єктам господарювання відбувається повільнішими темпами порівняно з кредитами фізичним особам, що, в тому числі, вказує на застосування менш ефективних засобів аналізу кредитоспроможності юридичних осіб.

З метою зниження частки непрацюючих кредитів виникає потреба у проведенні ефективної оцінки кредитоспроможності позичальника на етапі розгляду кредитної заявки. Сучасні інструменти економіко-математичного моделювання допомагають істотно підвищити точність оцінювання, що мінімізуватиме збитки банківської установи та допоможе підвищити прибуток шляхом збільшення об'ємів активних операцій комерційного банку.

**Аналіз останніх досліджень і публікацій.** Традиційно методи класифікації позичальників поділяються на 2 типи: параметричні (дискримінантний аналіз [3, 4], логістична регресія [5, 6] тощо) та непараметричні, що застосовуються дедалі частіше, оскільки не ґрунтуються на припущеннях щодо розподілу вхідних даних (дерева прийняття рішень [6, 7], нейронні мережі [3, 8, 9, 10], нечітка логіка [11–13], генетичні алгоритми [14], метод  $k$ -найближчих сусідів [15] та ін.). Серед непараметричних методів найчастіше використовують інструментарій штучних нейронних мереж і нечіткої логіки. Однак, нечітка логіка вимагає експертного встановлення правил прийняття рішень, що вносить певну суб'єктивність до розрахунків, є доволі складною у застосуванні та демонструє близькі до інших непараметричних методів результати класифікації. Нейронні мережі позбавлені цих недоліків, характеризуються високою адаптивністю та здатністю до самонавчання (узагальнення), що підвищує точність моделювання. Наприклад, у дослідженні Веста Д. [8] проаналізовано 5 типів нейронних мереж, котрі можуть бути застосовані для оцінки надійності позичальника: багат шаровий персептрон (MLP), радіально-базисна функція (RBF), векторне квантування (LVQ), нечіткий адаптивний резонанс (FAR) і комітет експертів (об'єднання нейронних мереж різних типів), що, відповідно до результатів дослідження, виявився найточнішою архітектурою для оцінки кредитоспроможності. Проблематика застосування нейронних мереж для розв'язання задач моделювання кредитних ризиків до-

сліджена у працях вітчизняних науковців Великоіваненко Г. І. [16, 17], Матвійчука А. В. [18], Савіної С. С., Беня В. П. [19, 20], Мінца О. Ю. [21] та ін. Проте питання вибору оптимальної архітектури нейромережі та її конфігурації для класифікації юридичних осіб-позичальників банків потребує подальшого ґрунтовного дослідження.

**Метою статті** є проведення експериментального дослідження з пошуку оптимальної архітектури та параметрів нейронних мереж перцептронного типу для вирішення задачі класифікації позичальників-юридичних осіб за рівнем кредитоспроможності.

**Виклад основного матеріалу.** Основним завданням оцінювання кредитного ризику є віднесення потенційного позичальника до одного з двох класів: «надійний позичальник», котрий імовірно виконає фінансове зобов'язання, або «ненадійний», чия кредитна заява повинна бути відхилена через високий ризик дефолту за фінансовим зобов'язанням [8].

У задачі класифікації позичальників-юридичних осіб за рівнем кредитного ризику нульовою гіпотезою є припущення про незадовільну кредитоспроможність потенційного позичальника. Відповідно, похибка I роду буде спостерігатись при віднесенні позичальника, котрий не виконає зобов'язання, до класу «надійних», похибка II роду — при віднесенні кредитоспроможного позичальника до класу «ненадійних». Похибка I роду є витратнішою для банківських установ, оскільки в такому разі позичальник втрачає як суму виданого кредиту, так і відсотки за ним. При похибці II роду банк лише недоотримує прибуток за відсотками по кредиту.

Проведений аналіз опублікованих праць з моделювання кредитоспроможності позичальників-юридичних осіб і власні дослідження з даного напрямку обумовили вибір нейронних мереж перцептронного типу для вирішення задачі класифікації позичальників за рівнем кредитного ризику та обґрунтування мети даної роботи. Основний блок такої мережі — формальний нейрон, що є алгоритмічно реалізованою моделлю, елементи якої мають прямі аналоги компонент біологічних нейронів. На вхід нейрона подаються сигнали  $x_i$ , при цьому з кожним входом пов'язана синаптична вага  $w_i$  (зв'язок між нейронами),  $i=1, n$ . У тілі нейрона вираховується функція активації, що перетворює багатовимірний простір входів на скалярний вихід:

$$y = \Psi \left( \sum_{i=1}^n w_i x_i + b \right), \quad (1)$$

де  $y$  — вихідний сигнал нейрона,  $n$  — кількість входів,  $x_i$  — значення  $i$ -го вхідного показника,  $w_i$  — вага  $i$ -го входу нейрона,  $b$  — параметр зміщення вхідного сигналу, що подається на функцію активації (*bias*),  $\Psi$  — функція активації нейрона [18, с. 44].

У даному дослідженні в якості функцій активації нейронів використовувались такі функції: експоненціальна (*exponential* у пакеті STATISTICA Neural Networks), гіперболічний тангенс (*tanh*), логістична (*logistic*) функція, а також функції тотожності (*identity*) та софтмакс (*softmax*) — для вихідного шару.

Побудова нейронної мережі передбачає такі кроки:

- 1) відбір пояснювальних змінних;
- 2) вибір типу мережі, функцій активації, співвідношення навчальної, тестової та контрольної вибірок;
- 3) навчання мереж і відбір найефективніших на основі тестової помилки;
- 4) перевірка адекватності навчання на основі контрольної похибки.

Для розв'язання задачі класифікації позичальників-юридичних осіб у даному дослідженні застосовувалась нейронна мережа типу багат шаровий персептрон (multilayer perceptron — MLP). До головних особливостей багат шарових персептронів належать: застосування нелінійних функцій активації; наявність одного або кількох шарів прихованих нейронів, що дозволяють мережі навчатись, поступово видобуваючи найважливіші ознаки з вхідного вектора; високий ступінь зв'язаності завдяки зміні синоптичних з'єднань і їх вагових коефіцієнтів [22, с. 220].

Архітектуру багат шарового персептрона з одним прихованим шаром представлено на рис. 2, де  $x_i$  — значення  $i$ -го вхідного показника,  $i = \overline{1, n}$ ;  $w_{il}^{(2)}$  — значення вагового коефіцієнта, що поєднує  $i$ -ий нейрон першого шару та  $l$ -ий нейрон другого шару нейронної мережі,  $l = \overline{1, p}$ ;  $w_{lj}^{(3)}$  — значення вагового коефіцієнта, що поєднує  $l$ -ий нейрон другого шару та  $j$ -ий нейрон третього шару нейронної мережі,  $j = \overline{1, m}$ ;  $y_j$  — значення  $j$ -го вихідного показника.




Рис. 2. Базова архітектура тришарового перцептрона

Джерело: [18, с. 53]

Перетворення вхідних сигналів у нейронах багатошарового перцептрона здійснюється з урахуванням вагових коефіцієнтів міжнейронних зв’язків за функцією:

$$y_j = \Psi_j^{(3)} \left( b_j^{(3)} + \sum_{l=1}^p \left[ w_{lj}^{(3)} \cdot \Psi_l^{(2)} \left( b_l^{(2)} + \sum_{i=1}^n \left[ w_{il}^{(2)} \cdot \Psi_i^{(1)}(x_i) \right] \right) \right] \right), \quad (2)$$

де  $\Psi_i^{(1)}(\cdot)$  — функція активації  $i$ -го,  $i = \overline{1, n}$ , нейрона вхідного шару нейронної мережі;

$\Psi_l^{(2)}(\cdot)$ ,  $b_l^{(2)}$  — функція активації та параметр зміщення суматора  $l$ -го,  $l = \overline{1, p}$ , нейрона другого шару;

$\Psi_j^{(3)}(\cdot)$ ,  $b_j^{(3)}$  — функція активації та параметр зміщення суматора  $j$ -го,  $j = \overline{1, m}$ , нейрона вихідного шару.

У багат шарових персептронах навчання проводиться із застосуванням алгоритму зворотного поширення помилки, що передбачає два проходження по всіх шарах мережі: пряме і зворотне. При прямому проходженні образ (вхідний вектор) подається на сенсорні вузли мережі, після чого поширюється мережею від шару до шару. Під час прямого проходження усі синаптичні ваги мережі фіксовані, а під час зворотного ваги налаштовуються згідно з правилом корекції помилок, а саме: фактичний вихід мережі віднімається від бажаного (цільового) відгуку, в результаті чого формується сигнал помилки. Цей сигнал поширюється мережею у напрямку, зворотному синаптичним зв'язкам. Синаптичні ваги налаштовуються з метою максимального наближення вихідного сигналу мережі до бажаного в статистичному сенсі [22, с. 220].

Пошук найбільш адекватної структури персептрона зумовлює необхідність проведення експериментів із великим числом мереж різних конфігурацій, інколи навчаючи кожну з них кілька разів і порівнюючи отримані результати. При цьому кількість нейронів вхідного шару відповідає кількості незалежних змінних, а число нейронів вихідного шару дорівнює 2. Головним критерієм вибору найбільш ефективної мережі є контрольна похибка.

У рамках даного дослідження побудова моделей проводилась з використанням пакету STATISTICA Neural Networks.

Генеральна сукупність, очищена від спостережень, що містили аномальні викиди та пропущені значення, складалась із записів стосовно понад 8000 позичальників (серед яких 390 зазнали дефолту). Кожний запис містить показники попередньої кредитної історії та дані бухгалтерської звітності підприємств на момент видачі кредиту, для яких було обраховано 70 фінансових показників. Оскільки використання такої кількості факторів на практиці неминуче призводить до «прокляття розмірності», нейромережі конструювались на основі від 6 до 20 пояснюючих змінних, відібраних за трьома критеріями: Джині (Gini), V Крамера (Cramer's V) та інформаційна значущість (Information Value).

У ході проведення дослідження встановлено, що найнижчі похибки I роду властиві для моделей, пояснюючі змінні яких відібрано на основі V Крамера. До первинного переліку незалежних змінних включено фінансові показники, що наведені у табл. 1.



Таблиця 1

## ПЕРЕЛІК ФІНАНСОВИХ ПОКАЗНИКІВ ДЛЯ ПОБУДОВИ МОДЕЛЕЙ

Незалежна змінна	V Крамера	Фінансовий показник
<i>K1</i>	0,6379	Наявність дефолту за попередніми зобов'язаннями
<i>K2</i>	0,6351	Покриття боргу операційним грошовим потоком
<i>K3</i>	0,6069	Відношення операційного грошового потоку до фінансових витрат
<i>K4</i>	0,5958	Покриття боргу чистим доходом
<i>K5</i>	0,5706	Рентабельність виробництва
<i>K6</i>	0,5678	Оборотність дебіторської заборгованості
<i>K7</i>	0,5675	Рентабельність продажу
<i>K8</i>	0,5660	Маневреність робочого капіталу
<i>K9</i>	0,5531	Коефіцієнт фінансової незалежності
<i>K10</i>	0,5491	Частка боргу в активах підприємства
<i>K11</i>	0,5454	Відношення інвестицій у необоротні активи до амортизації
<i>K12</i>	0,5425	Оборотність активів
<i>K13</i>	0,5408	Рентабельність активів (ROE)
<i>K14</i>	0,5396	Відношення боргу до доходу
<i>K15</i>	0,5381	Відношення довгострокових зобов'язань до суми основних засобів та оборотних активів
<i>K16</i>	0,5331	Покриття боргу валовим прибутком
<i>K17</i>	0,5301	Відношення фінансових витрат до валового прибутку
<i>K18</i>	0,5224	Динаміка обсягу прибутку до вирахування витрат за відсотками, сплати податків та амортизаційних відрахувань за мінусом нефінансованих капітальних витрат (cash EBITDA)
<i>K19</i>	0,5095	Прибутковість активів
<i>K20</i>	0,5078	Рентабельність власного капіталу

Джерело: розроблено автором

При роботі з усією генеральною сукупністю, де частка ненадійних позичальників становила лише 5 %, побудова адекватної моделі була неможливою, адже при такому співвідношенні надійних і ненадійних позичальників середня точність класифікації досягає 95,42 %, за якої похибка другого роду становить 0,07 %, у той час як похибка першого роду для деяких моделей сягає 100 %. Тому було прийнято рішення працювати з вибіркою, де спостереження з обох класів представлені у співвідношенні 50 % / 50 %, у результаті чого обсяг генеральної сукупності зменшено до 798 спостережень задля забезпечення однакової репрезентативності надійних і ненадійних позичальників.

У ході дослідження проаналізовано більше ніж 3000 моделей типу багатосаровий персептрон. Виявлено, що оптимальні результати класифікації позичальників, котрі зазнали дефолту, досягаються за умови поділу генеральної сукупності на навчальну, тестову та контрольну вибірки у пропорції 70 : 15 : 15 (ілюстрацію такого дослідження наведено на рис. 3).

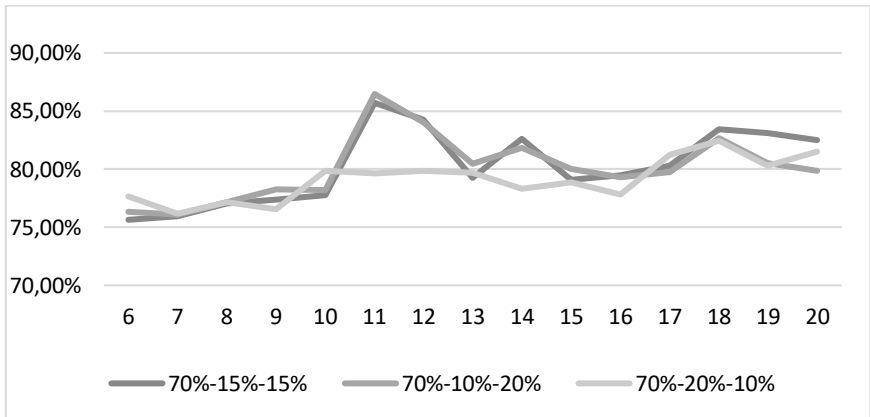


Рис. 3. Точність класифікації позичальників, які зазнали дефолту, при різній кількості факторів і пропорціях навчальних, тестових та контрольних вибірок

Джерело: розроблено автором

Розмір навчальної вибірки залишався на рівні 70 % для достатньої репрезентативності обох класів позичальників. Середня

точність класифікації позичальників, котрі зазнали дефолту, за різних пропорцій тестових і контрольних вибірок становить відповідно:

- 1) 70 % : 15 % : 15 % — 80,23 %;
- 2) 70 % : 10 % : 20 % — 80,06 %;
- 3) 70 % : 20 % : 10 % — 79,13 %.

Збільшення частки контрольної або тестової вибірки до 20 % при контрольній перевірці не приводить до зменшення помилки I роду.

Також з рис. 3 можна бачити, що оптимальна кількість незалежних змінних для адекватної оцінки кредитоспроможності юридичних осіб становить не менше 11.

Наведемо у табл. 2 перелік найадекватніших моделей, розрахованих для випадку, коли розмір навчальної вибірки становить 70 % від обсягу генеральної сукупності, тестової — 15 %, контрольної — 15 %.

Таблиця 2

**ПОКАЗНИКИ АДЕКВАТНОСТІ МОДЕЛЕЙ ТИПУ  
БАГАТОШАРОВИЙ ПЕРСЕПТРОН РІЗНИХ КОНФІГУРАЦІЙ**

Архітектура мережі, кількість входів, кількість нейронів проміжного та вихідного шару	Відсоток правильно класифікованих позичальників у навчальній вибірці, %	Відсоток правильно класифікованих позичальників у тестовій вибірці, %	Відсоток правильно класифікованих позичальників у контрольній вибірці, %	Функція активації прихованого шару	Функція активації вихідного шару
MLP 11-6-2	91,52	90,68	90,68	гіперболічний тангенс	софтмакс
MLP 12-8-2	91,70	90,68	91,53	логістична	софтмакс
MLP 13-15-2	92,06	90,68	92,37	гіперболічний тангенс	софтмакс
MLP 14-10-2	91,70	91,53	92,37	гіперболічний тангенс	софтмакс
MLP 18-14-2	93,66	92,37	92,37	гіперболічний тангенс	софтмакс

Джерело: розроблено автором

Як свідчать дані табл. 2, відібрані пояснюючі змінні є достатніми для побудови адекватних моделей, адже відсоток правильно класифікованих позичальників-юридичних осіб із контрольної вибірки знаходиться на одному рівні з аналогічним показником для тестової вибірки, а в окремих випадках навіть перевищує його. Для побудованих моделей властиві досить низькі значення похибки I роду (висока точність класифікації позичальників, що зазнали дефолту). У табл. 3 наведено точність діагностування підприємств з обох класів найефективнішими нейромережами (позичальники, котрі зазнали дефолту, позначені через «1», а які виконали зобов'язання — через «0»).

Таблиця 3

## ТОЧНІСТЬ КЛАСИФІКАЦІЇ ПОЗИЧАЛЬНИКІВ

Архітектура мережі, кількість входів, кількість нейронів проміжного та вихідного шару	Клас позичальника	Відсоток правильно класифікованих спостережень
MLP 11-6-2	0	96,22
	1	86,31
MLP 12-8-2	0	95,88
	1	87,07
MLP 13-15-2	0	97,25
	1	86,31
MLP 14-10-2	0	96,22
	1	86,69
MLP 18-14-2	0	97,59
	1	89,31

Отже, для відібраних у ході проведення дослідження моделей похибка I роду становить 10,69 %–13,69 %, що свідчить про їх адекватність і можливість застосування банківськими установами при оцінці кредитоспроможності позичальників-юридичних осіб.

**Висновки.** У дослідженні запропоновано використання багат шарових перцептронів для оцінки кредитоспроможності позичальників-юридичних осіб. Побудова моделей передбачала етапи: 1) відбір пояснювальних змінних; 2) вибір типу мережі, функцій

активації, співвідношення навчальної, тестової та контрольної вибірок; 3) навчання мереж та відбір найефективніших на основі тестової помилки; 4) перевірка адекватності навчання на основі контрольної похибки. Проведено експериментальне дослідження із більше ніж 3000 моделями типу багатошаровий перцептрон у інструментальному пакеті STATISTICA Neural Networks. Виявлено, що оптимальні результати діагностування позичальників, котрі зазнали дефолту, досягаються за умови поділу генеральної сукупності на навчальну, тестову та контрольну вибірки у пропорції 70 % : 15 % : 15 %.

Оптимальна кількість пояснювальних змінних для адекватної оцінки кредитоспроможності юридичних осіб становить більше 10. За таких умов середня точність класифікації позичальників, що зазнали дефолту становить 80,23 %. Для п'яти найефективніших моделей, відібраних у ході дослідження (MLP 11-6-2, MLP 12-8-2, MLP 13-15-2, MLP 14-10-2, MLP 18-14-2), похибка I роду становила 10,69 %–13,69 %, що підтверджує можливість їхнього використання банківськими установами при оцінці кредитоспроможності позичальників-юридичних осіб.

## Список літератури

1. Звіт про фінансову стабільність, червень 2019 р. *Національний банк України* : веб-сайт. URL: [https://nbu1.bank.gov.ua/admin\\_uploads/article/FSR\\_2019-R1.pdf](https://nbu1.bank.gov.ua/admin_uploads/article/FSR_2019-R1.pdf).
2. Огляд банківського сектору, серпень 2019 року. *Національний банк України* : веб-сайт. URL: [https://bank.gov.ua/file/download?file=Banking\\_Sector\\_Review\\_2019-08.pdf](https://bank.gov.ua/file/download?file=Banking_Sector_Review_2019-08.pdf).
3. Новоселецький О. М., Якубець О. В. Моделювання кредитоспроможності юридичних осіб на основі дискримінантного аналізу та нейронних мереж. *Нейро-нечіткі технології моделювання в економіці*. 2014. № 3. С. 120–150. URL: [http://nfmte.com/assets/journal/3/Novoseletskyy\\_Yakubets.pdf](http://nfmte.com/assets/journal/3/Novoseletskyy_Yakubets.pdf).
4. Casin P. Categorical multiblock linear discriminant analysis. *Journal of Applied Statistics*. 2017. Vol. 45, No 8. P. 1396–1409. DOI: 10.1080/02664763.2017.1371678.
5. Савіна С. С., Бень В. П. Об'єднання моделей логіт-регресій як комітету експертів для оцінки кредитоспроможності позичальника. *Нейро-нечіткі технології моделювання в економіці*. 2015. № 4. С. 154–188. URL: [http://nfmte.com/assets/journal/4/Savina\\_Ben.pdf](http://nfmte.com/assets/journal/4/Savina_Ben.pdf).

6. Joos P., Vanhoof K., Sierens N., Ooghe H. Credit classification: a Comparison of Logit Models and Decision trees. *Proceedings notes of the Workshop on Application of Machine Learning and Data Mining in Finance*. 1998. P. 59–72.
7. Malik R., Hermawan H. Credit Scoring Using CART Algorithm and Binary Particle Swarm Optimization. *International Journal of Electrical & Computer Engineering*. 2018. Vol. 8, No. 6. P. 5425–5431. DOI: 10.11591/ijece.v8i6.pp5425-5431.
8. West D. Neural Network Credit Scoring Models. *Computers & Operations Research*. 2000. Vol. 27, No. 11–12. P. 1131–1152. DOI: 10.1016/s0305-0548(99)00149-5.
9. Zhao Z., Xu S., Kang B. H., Kabir M. M. J., Liu Y., Wasinger R. Investigation and improvement of multi-layer perception neural networks for credit scoring. *Expert Systems with Applications*. 2015. Vol. 42, No. 7. P. 3508–3516. DOI: 10.1016/j.eswa.2014.12.006.
10. Tsai C., Wu J. Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications*. 2008. Vol. 34, No. 4. P. 2639–2649. DOI: 10.1016/j.eswa.2007.05.019.
11. Akkoç S. Exploring the nature of credit scoring: a neuro fuzzy approach. *Fuzzy Economic Review*. 2019. Vol. 24, No. 1. P. 3–24. DOI: 10.25102/fer.2019.01.01.
12. Клебан Ю. В. Діагностика платоспроможності підприємств із застосуванням нечіткої моделі Такагі-Сугено. *Нейро-нечіткі технології моделювання в економіці*. 2015. № 4. С. 62–79. URL: <http://nfimte.com/assets/journal/4/Kleban.pdf>.
13. Matviychuk A. Bankruptcy prediction in transformational economy: discriminant and fuzzy logic approaches. *Fuzzy economic review*. 2010. Vol. XV, No. 1. P. 21–38. DOI: 10.25102/fer.2010.01.02.
14. Huang J., Tzeng G., Ong C. Two-stage genetic programming (2SGP) for the credit scoring model. *Applied Mathematics and Computation*. 2006. Vol. 174, No. 2. P. 1039–1053. DOI: 10.1016/j.amc.2005.05.027.
15. Mukid M. A., Widiharih T., Rusgiyono A., Prahutama A. Credit scoring analysis using weighted k nearest neighbor. *Journal of Physics: Conference Series*. 2018. Vol. 1025. P. 1–7. DOI: 10.1088/1742-6596/1025/1/012114.
16. Великоіваненко Г. І., Корчинський В. В., Чернишова В. В. Дослідження ефекту перенавчання нейронних мереж на прикладі задачі аплікаційного скорингу. *Нейро-нечіткі технології моделювання в економіці*. 2016. № 5. С. 3–23. URL: [http://nfimte.com/assets/journal/5/Velykoivanenko\\_Chernyshova\\_Korchynskiyi.pdf](http://nfimte.com/assets/journal/5/Velykoivanenko_Chernyshova_Korchynskiyi.pdf).
17. Великоіваненко Г. І., Трокоз Л. О. Нейро-нечітка модель оцінювання прострочених позик комерційного банку. *Нейро-нечіткі технології моделювання в економіці*. 2014. № 3. С. 23–66. URL: [http://nfimte.com/assets/journal/3/Velykoivanenko\\_Trokoz.pdf](http://nfimte.com/assets/journal/3/Velykoivanenko_Trokoz.pdf).

18. Матвійчук А. В. Штучний інтелект в економіці: нейронні мережі, нечітка логіка: монографія. К.: КНЕУ, 2011. 439 с.
19. Великоіваненко Г. І., Савіна С. С., Колечко Д. В., Бень В. П. Побудова ансамблів моделей кредитного скорингу. *Нейро-нечіткі технології моделювання в економіці*. 2018. № 7. С. 34–77. DOI: 10.33111/nfmte.2018.034.
20. Савіна С. С., Бень В. П. Вибір архітектури нейромережі для розв'язання задачі класифікації надійності позичальників-фізичних осіб. *Нейро-нечіткі технології моделювання в економіці*. 2016. № 5. С. 123–151. URL: [http://nfmte.com/assets/journal/5/Savina\\_Ben'.pdf](http://nfmte.com/assets/journal/5/Savina_Ben'.pdf).
21. Мінц О. Ю. Методологія моделювання інноваційних інтелектуальних систем прийняття рішень в економіці: монографія. Маріуполь: ДВНЗ «Приазовський державний технічний університет», 2017. 216 с.
22. Хайкин С. Нейронные сети: полный курс, 2-е издание. М.: Издательский дом «Вильямс», 2006. 1104 с.

## References

1. The National Bank of Ukraine. (2019). *Zvit pro finansovu stabilnist, cherven 2019 r.* Retrieved from [https://bank.gov.ua/admin\\_uploads/article/FSR\\_2019-R1.pdf?v=4](https://bank.gov.ua/admin_uploads/article/FSR_2019-R1.pdf?v=4) [in Ukrainian].
2. The National Bank of Ukraine. (2019). *Ohliad bankivskoho sektoru, serpen 2019 r.* Retrieved from [https://bank.gov.ua/file/download?file=Banking\\_Sector\\_Review\\_2019-08.pdf](https://bank.gov.ua/file/download?file=Banking_Sector_Review_2019-08.pdf) [in Ukrainian].
3. Novoseletskyi, O. M., & Yakubets, O. V. (2014). Modeliuvannia kredytopromozhnosti yurydychnykh osib na osnovi dyskryminantnoho analizu ta neironnykh merezh. *Nejro-nechitki tekhnolohii modeliuvannia v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 3, 120–150. Retrieved from [http://nfmte.com/assets/journal/3/Novoseletskyy\\_Yakubets.pdf](http://nfmte.com/assets/journal/3/Novoseletskyy_Yakubets.pdf) [in Ukrainian].
4. Casin, P. (2017). Categorical multiblock linear discriminant analysis. *Journal of Applied Statistics*, 45(8), 1396–1409. DOI: 10.1080/02664763.2017.1371678.
5. Savina, S. S., & Ben, V. P. (2015). Obiednannia modelei logit-rehresii yak komitetu ekspertiv dlia otsinky kredytopromozhnosti pozychalnyka. *Nejro-nechitki tekhnolohii modeliuvannia v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 4, 154–188. Retrieved from [http://nfmte.com/assets/journal/4/Savina\\_Ben.pdf](http://nfmte.com/assets/journal/4/Savina_Ben.pdf) [in Ukrainian].
6. Joos, P., Vanhoof, K., Sierens, N., & Ooghe, H. (1998). Credit classification: a Comparison of Logit Models and Decision trees. *Proceedings notes of the Workshop on Application of Machine Learning and Data Mining in Finance*, 59–72.

7. Malik, R. F., & Hermawan, H. (2018). Credit Scoring Using CART Algorithm and Binary Particle Swarm Optimization. *International Journal of Electrical & Computer Engineering*, 8(6), 5425–5431. DOI: 10.11591/ijece.v8i6.pp5425–5431.
8. West, D. (2000). Neural Network Credit Scoring Models. *Computers & Operations Research*, 27(11–12), 1131–1152. DOI: 10.1016/s0305-0548(99)00149-5.
9. Zhao, Z., Xu, S., Kang, B. H., Kabir, M. M. J., Liu, Y., & Wasinger, R. (2015). Investigation and improvement of multi-layer perceptron neural networks for credit scoring. *Expert Systems with Applications*, 42(7), 3508–3516. DOI: 10.1016/j.eswa.2014.12.006.
10. Tsai, C., & Wu, J. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 34(4), 2639–2649. DOI: 10.1016/j.eswa.2007.05.019.
11. Akkoç, S. (2019). Exploring the nature of credit scoring: a neuro fuzzy approach. *Fuzzy Economic Review*, 24(1), 3–24. DOI: 10.25102/fer.2019.01.01.
12. Kleban, Yu. V. (2015). Diahnostyka platospromozhnosti pidpriemstv iz zastosuvanniam nechitkoi modeli Takagi-Sugeno. *Nejro-nechitki tekhnologii modeliuвання v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 4, 62–79. Retrieved from <http://nfimte.com/assets/journal/4/Kleban.pdf> [in Ukrainian].
13. Matviychuk, A. (2010). Bankruptcy prediction in transformational economy: discriminant and fuzzy logic approaches. *Fuzzy economic review*, 15(1), 21–38. DOI: 10.25102/fer.2010.01.02.
14. Huang, J., Tzeng, G., & Ong, C. (2006). Two-stage genetic programming (2SGP) for the credit scoring model. *Applied Mathematics and Computation*, 174(2), 1039–1053. DOI: 10.1016/j.amc.2005.05.027.
15. Mukid, M. A., Widiharih, T., Rusgiyono, A., & Prahutama, A. (2018). Credit scoring analysis using weighted k nearest neighbor. *Journal of Physics: Conference Series*, 1025, 1–7. DOI: 10.1088/1742-6596/1025/1/012114.
16. Velykoivanenko, H. I., Korchynskiy, V. V., & Chernyshova, V. V. (2016). Doslidzhennia efektu perenavchannia neironnykh merezh na prykladi zadachi aplikatsiinoho skorynhu. *Nejro-nechitki tekhnologii modeliuвання v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 5, 3–23. Retrieved from [http://nfimte.com/assets/journal/5/Velykoivanenko\\_Chernyshova\\_Korchynskiy.pdf](http://nfimte.com/assets/journal/5/Velykoivanenko_Chernyshova_Korchynskiy.pdf) [in Ukrainian].
17. Velykoivanenko, H. I., & Trokoz, L. O. (2014). Neuro-nechitka model otsiniuvannia prostrochenykh pozyk komertsiiinoho banku. *Nejro-nechitki tekhnologii modeliuвання v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 3, 23–66. Retrieved from [http://nfimte.com/assets/journal/3/Velykoivanenko\\_Trokoz.pdf](http://nfimte.com/assets/journal/3/Velykoivanenko_Trokoz.pdf) [in Ukrainian].



18. Matviychuk, A. V. (2011). *Shtuchnyi intelekt v ekonomitsi: neuronni merezhi, nechitka lohika: monohrafiia*. Kyiv, Ukraine: KNEU [in Ukrainian].
19. Velykoivanenko, H. I., Savina, S. S., Kolechko, D. V., & Ben, V. P. (2018). Pobudova ansambliv modelei kredytnoho skorynhu. *Nejro-nechitki tekhnologii modeliuvannia v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 7, 34–77. DOI: 10.33111/nfmte.2018.034 [in Ukrainian].
20. Savina, S. S., & Ben, V. P. (2016). Vybir arkhitektury neiromerezhi dlia rozviazannia zadachi klasyfikatsii nadiinosti pozychalnykiv-fizychnykh osib. *Nejro-nechitki tekhnologii modeliuvannia v ekonomitsi (Neuro-Fuzzy Modeling Techniques in Economics)*, 5, 123–151. Retrieved from [http://nfmte.com/assets/journal/5/Savina\\_Ben'.pdf](http://nfmte.com/assets/journal/5/Savina_Ben'.pdf) [in Ukrainian].
21. Mints, O. Yu. (2017). *Metodolohiia modeliuvannia innovatsiinykh intelektualnykh system pryiniattia rishen v ekonomitsi: monohrafiia*. Mariupol, Ukraine: DVNZ “Pryazovskyi derzhavnyi tekhnichniy universytet” [in Ukrainian].
22. Haykin, S. (1998). *Neural Networks — A Comprehensive Foundation, Second Edition*. New Jersey, NJ: Prentice-Hall.

Стаття надійшла до редакції 11.08.2019